

# Hispanic Medieval Tagger (HisMeTag): una aplicación web para el etiquetado de entidades en textos medievales

M. Luisa Díez Platas  
LINHD-UNED  
Llanos Tobarra  
UNED  
Salvador Ros  
UNED  
Elena González-Blanco  
UNED  
Antonio Robles-Gómez  
UNED  
Agustín C. Caminero  
UNED  
Gimena del Río Riande  
IIBICRIT, CONICET

## 1. Introducción

El impacto de las nuevas tecnologías en la investigación en el ámbito de las humanidades ha supuesto una revolución en la recopilación, acceso y representación de la información así como en el procesamiento de los grandes volúmenes de datos y textos. Es en este contexto y como respuesta a las necesidades crecientes de los proyectos de investigación, en el que surge el término Humanidades Digitales (DH, *Digital Humanities*) como punto de conexión de distintas disciplinas y que establece la relación entre las nuevas tecnologías y las diferentes comunidades científicas (Del Río Riande, 2016) (González-Blanco, 2013)

El creciente uso de la computación en la nube para facilitar la gestión de proyectos humanísticos ha dado lugar a distintas iniciativas como los Entornos Virtuales de Investigación (VRE, *Virtual Research Environments*) (Bellamy, 2012) desarrollados preferentemente en laboratorios y centros de investigación interdisciplinarios especializados en Humanidades Digitales como, entre otros, el Laboratorio de Innovación en Humanidades Digitales de la UNED ([LINHD](#))

Las Humanidades Digitales han establecido originariamente fuertes vínculos con la filología (un testimonio significativo es el consorcio TEI, creador del lenguaje de marcado que abandera esta disciplina) y, sin embargo, en los últimos años, la tendencia hacia la automatización ha provocado que el análisis textual se haya orientado hacia la lingüística computacional y el área de procesamiento del lenguaje natural (PLN), ámbitos que tradicionalmente no se asociaban con las humanidades en sí mismas. El proyecto [POSTDATA](#) (*Poetry Standardization and Linked Open Data*), que participa de esta tendencia, incorpora en uno de sus paquetes de trabajo el tratamiento computacional del texto en combinación con el análisis semántico de las categorías poéticas. En el seno de este proyecto ha tenido lugar la creación de una de sus primeras aplicaciones, a herramienta *Hispanic Medieval Tagger* (HisMeTag).

HisMeTag permite localizar entidades nombradas en textos escritos en español medieval, mediante un proceso automático de reconocimiento de entidades nombradas (NER) y técnicas de PLN para el procesamiento lingüístico y la generación de las distintas variantes que existieron en la época medieval. Localiza, etiqueta términos conocidos y propone nuevos términos para su validación.

La accesibilidad, las distintas formas de visualización, la posibilidad de edición y la capacidad de presentar resultados para su análisis son elementos clave para asegurar el éxito y la funcionalidad de HisMetag, para lo que se ha considerado oportuno construir una plataforma web, funcional y usable.

Sin la intervención explícita del usuario, se transforma un documento textual inicial, bien en formato de texto sencillo o en XML-TEI (TEIConsortium, 2015) en otro documento en formato XML-TEI, pero enriquecido con información sobre los nombres propios, junto con diversos archivos de visualización (en formato HTML o CSV) que incluyen información relevante y totalmente preparada para su futuro análisis, o incluso para ser insertados en proyectos de investigación directamente, si fuera necesario.

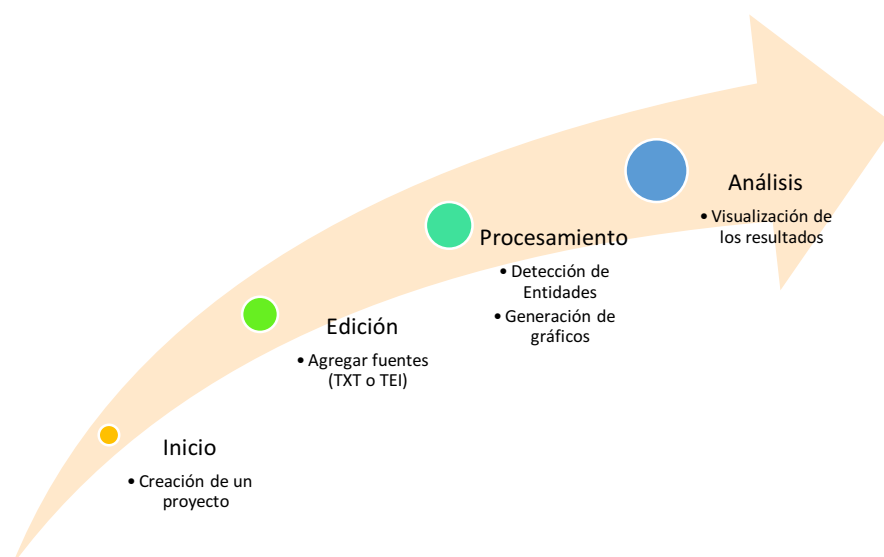
## 2. *Hispanic Medieval Tagger* (HisMeTag )

La aplicación web *HisMeTag* está orientada al análisis de textos medievales teniendo en cuenta las variantes lingüísticas y sus especiales características sintácticas para obtener información sobre las entidades nombradas mencionados en el texto.

Para esta primera demostración de la herramienta se han seleccionado dos textos medievales castellanos del Siglo XIII de distinta naturaleza: un documento notarial de la época alfonsí y un fragmento del *Libre dels tres reys d'Orient* (Gago Jover, 2011).

La metodología de desarrollo de la aplicación web ha seguido el patrón modelo-vista-controlador desarrollada en *Python* y basada en el *microframework Flask* (Ronacher, 2017). La interfaz se ha creado mediante plantillas Jinja2 (Ronacher, Jinja, 2017) y la biblioteca *Bootstrap* para desplegar un sitio web basado en HTML5, accesible y adaptable.

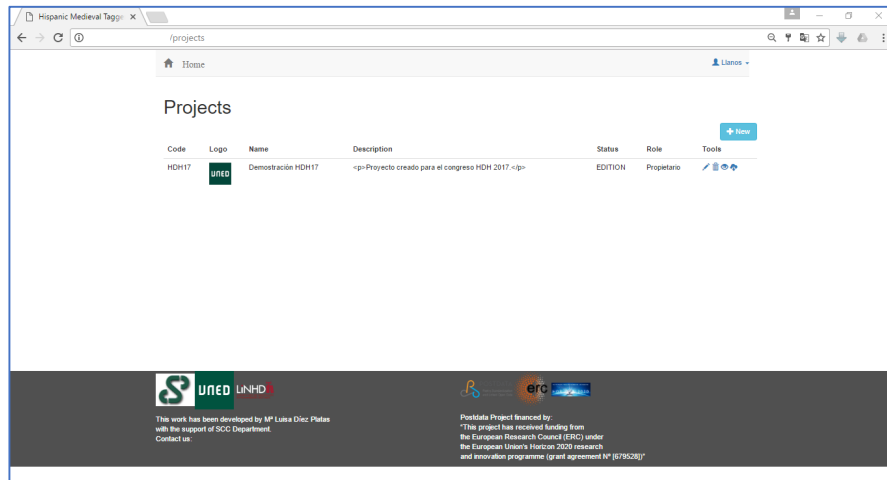
El flujo de trabajo de la aplicación web es el siguiente:



Las funcionalidades que proporciona la herramienta se describen a continuación:

- Acepta archivos de entrada de texto TXT y archivos XML-TEI.

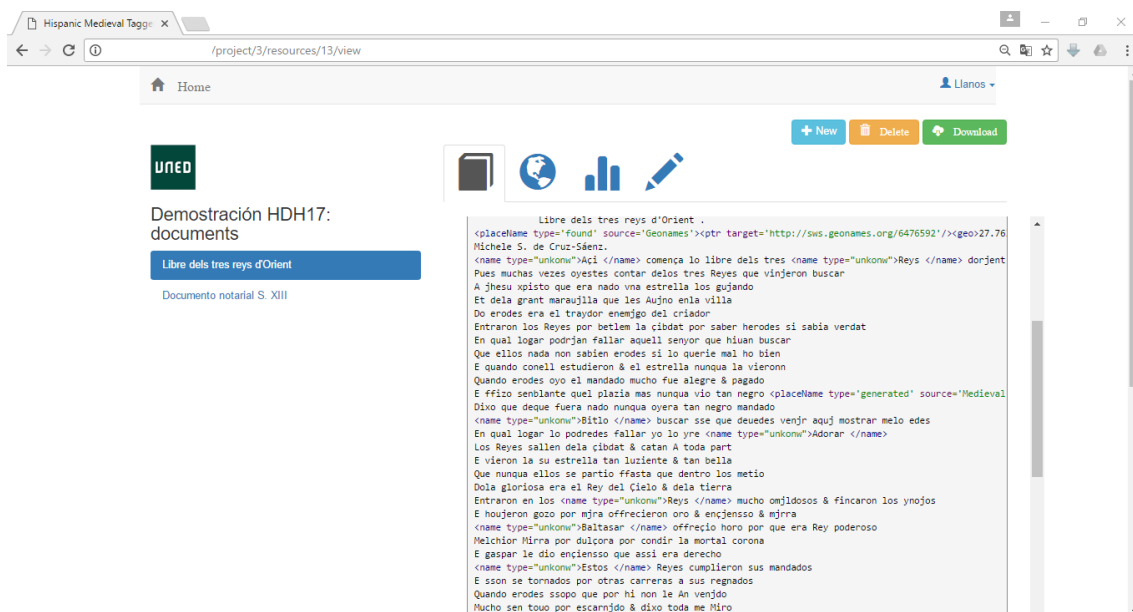
- Permite agrupar diferentes documentos con diferentes versiones para el análisis conjunto o independiente. Los corpus de textos se pueden organizar mediante proyectos para cada usuario registrado.



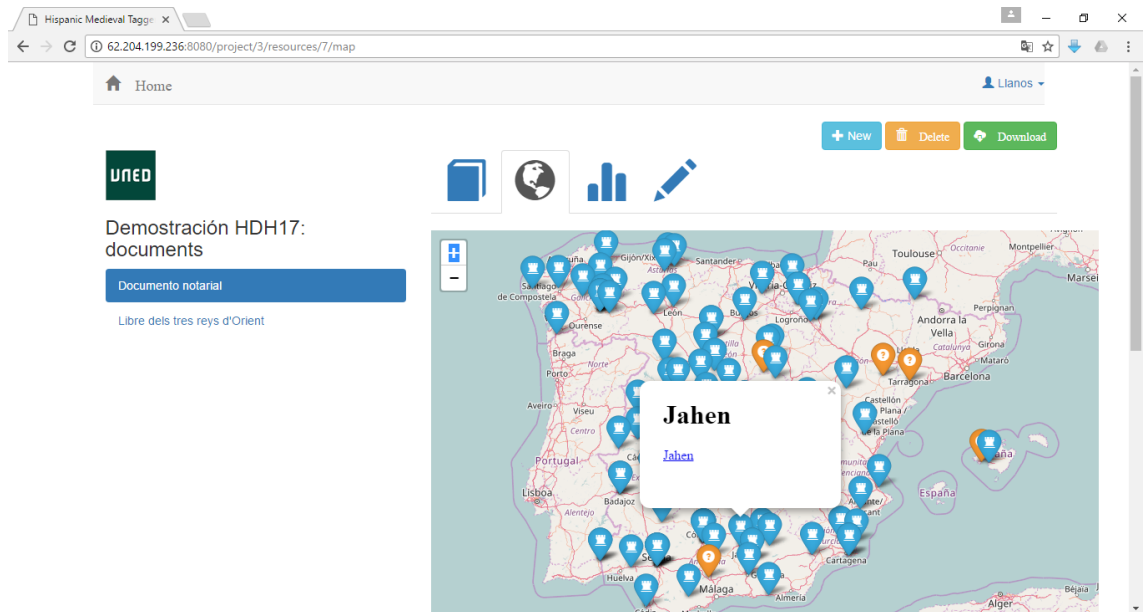
- Permite incorporar información descriptiva sobre textos que será incorporada al archivo XML-TEI de salida como metadatos
- Reconoce entidades nombradas de distinta naturaleza mediante el uso de *Gazetteers*, diccionarios y lexicones
- Realiza reconocimiento de variantes de nombres mediante un proceso de generación de variantes asociadas y reconocidas aplicando transformaciones morfológicas y fonéticas propias de la norma y la evolución lingüística de la época medieval (por ejemplo, Seulia sería asociado a Sevilla tras la transformación)
- Cataloga términos no reconocidos de acuerdo con el contexto semántico de aparición
- Resuelve términos ambiguos usando contextos semánticos

Los resultados se visualizan de diferentes formas:

- Archivo XML-TEI con todas las entidades etiquetadas.



- Archivos CSV con las entidades reconocidas y características
- Mapa geográfico de las localizaciones identificadas. Para crear el mapa la aplicación utiliza el servicio cartográfico *Leaflet* (Vladimir & OpenMaps, s.f.), que permite generar mapas anotados. En el mapa se muestran los lugares que se han identificado con su ubicación actual. Existen otros términos geográficos que no es posible representar porque se ignora su ubicación actual; por ejemplo, la Atlántida. También se incluyen términos ambiguos que podrían interpretarse tanto como nombres de persona como de lugar; como por ejemplo el término Moya, que corresponde tanto a un pueblo como a un apellido. Este mapa se almacena en un fichero HTML para su posterior exportación.



- Gráficas que se generan usando el paquete *Python Bokeh* (Continuum Analytics, 2015). Esta biblioteca genera gráficos interactivos con opciones como zoom o selección de solo un fragmento, posibilitando descargar los gráficos resultantes en una imagen. También se genera una página web HTML que facilita la exportación de los gráficos con las herramientas que proporciona *Bokeh*. En estas gráficas se presentan:
  - la frecuencia absoluta para todos los términos descubiertos,
  - el número de términos localizados por categorías,
  - la distribución de apariciones de cada entidad en el texto.



## Referencias

- Continuum Analytics. (2015). *Welcome to Bokeh*. Retrieved from <http://bokeh.pydata.org/en/latest/>
- Bellamy, C. (2012). The Sound of Many Hands Clapping: Teaching the Digital Humanities through Virtual Research Environment (VREs). *Digital Humanities Quarterly*, 6(2). Retrieved from <http://www.digitalhumanities.org/dhq/vol/6/2/000119/000119.html>
- Del Río Riande, G. (2016, Marzo 22). Humanidades Digitales. Construcciones locales en contextos globales. SEDICIBlog. Retrieved Mayo 28, 2017, from <http://sedici.unlp.edu.ar/blog/2016/03/22/humanidades-digitales-construcciones-locales-en-contexto>
- Del Río Riande, G., González-Blanco, E., Martínez-Cantón, C., Ros, S., Robles-Gómez, A., Pastor, R., . . . Caminero, A. (2017). EVI-LINHD, A Virtual Research Environment for the Spanisk-Speaking Community. *Digital Scholarship in the Humanities (DSH)* (accepted for publication).
- Gago Jover, F. (2011). "*Libre dels tres reys d'Orient*", *Textos Poéticos Españoles. Digital Library of Old Spanish Texts. Hispanic Seminary of Medieval Studies*. Retrieved from <http://www.hispanicseminary.org/t&c/poe/docs/text.tro.htm>
- González-Blanco, E. (2013). Actualidad de las Humanidades Digitales y un ejemplo de ensamblaje poético en la red: ReMetCa. *Cuadernos Hispanoamericanos*, 53-67.
- Ronacher, A. (2017). *Flask, web development, one drop at a time*. Retrieved from <http://flask.pocoo.org/>
- Ronacher, A. (2017). *Jinja*. Retrieved from <http://jinja.pocoo.org/docs/2.9/>
- TEI Consortium. (2015). *Text Encoding Initiative*. Retrieved from <http://www.tei-c.org/Guidelines/P5/>
- Vladimir, A., & OpenMaps. (n.d.). *Leaflet, an open-source JavaScript library for mobile-friendly interactive maps*. Retrieved from <http://leafletjs.com/>